

Review | Received: 01-12-2016 | Accepted: 14-12-2016

Geoinformation Generalization by Aggregation

Tomislav JOGUN, Nada VUČETIĆ and Dražen TUTIĆ*

University of Zagreb, Faculty of Geodesy, Kačićeva 26, 10000 Zagreb, Croatia
 tjogun1@hotmail.com, nvucetic@geof.hr, dtutic@geof.hr

*Since one co-author is the journal's editor-in-chief, the peer review process and independent editorial decision were performed by an external editor, Assoc. Prof. Robert Župan (associate editor of the journal *Geodetski list*, ISSN: 0016-710X and member of the Editorial Board of *AJET – Asian Journal of Engineering and Technology*, ISSN: 2321-2462). We thank Assoc. Prof. Robert Župan for his help in addressing potential editorial conflict of interest.

Abstract. Geoinformation generalization can be divided into model generalization and cartographic generalization. Model generalization is the supervised reduction of data in a model, while cartographic generalization is the reduction of the complexity of map content adapted to the map scale, and/or use by various generalization operators (procedures). The topic of this paper is the aggregation of geoinformation. Generally, aggregation is the joining of nearby, congenial objects, when the distance between them is smaller than the minimum sizes. Most researchers in geoinformation generalization have focused on line features. However, the appearance of web-maps with point features and choropleth maps has led to the development of concepts and algorithms for the generalization of point and polygonal features. This paper considers some previous theoretical premises and actual examples of aggregation for point, line and polygonal features. The algorithms for aggregation implemented in commercial and free GIS software were tested. In the conclusion, unresolved challenges that occur in dynamic cartographic visualizations and cases of unusual geometrical features are highlighted.

Keywords: aggregation, geoinformation generalization, generalization operator, cartographic generalization, GIS, web-maps

1 Introduction

With the development of digital technology over the past two decades, the production and use of maps have changed drastically. Whereas twenty years ago, the main navigation tool was a paper map, today's maps on mobile electronic devices provide users with information about locations, optimal routes, and desired locations. It could be claimed that a world without interactive maps on mobile phones and computers would be hard to imagine today.

Technological changes have exerted a major influence on the closely linked fields of cartography and geography. Geoinformation systems (GIS), as a tool in scientific research and geoinformatics as a science, are the subsequent response to this fundamental shift in technology within geography and related disciplines. A similar change has occurred in cartography, since the technological revolution has prompted a shift from analogue to digital cartography. The processes of map-making and map presentation have become faster, cheaper, more liberal and more diverse.

With the emergence of new output media, new opportunities and challenges have arisen, especially in cartographic generalization, which is a key process in cartography. Data abstraction is even more important in the information society, in which the volume of data available exceeds our capability to absorb it (Bereuter, 2015).

1.1 Terms and definitions

Geoinformation generalization is a broad term that can be divided into model generalization/database generalization (the derivation of a reduced database from a given one) and cartographic generalization (the process of derivation of a graphical product or visualization, either from a database or from another map in a larger scale) (Brassel and Weibel, 1988; Haunert and Wolff, 2010).

According to Frančula (2003), *cartographic generalization* is the process of reducing the complexity of map content, adapted to the map's scale and/or use.

To carry out cartographic generalization, various *generalization operators* are used to reduce spatial conflicts that

Generalizacija geoinformacija sažimanjem

Tomislav JOGUN, Nada VUČETIĆ i Dražen TUTIĆ*

Sveučilište u Zagrebu, Geodetski fakultet, Kačićeva 26, 10000 Zagreb
tjogun1@hotmail.com, nvucetic@geof.hr, dtutic@geof.hr

*S obzirom na to da je jedan koautor glavni urednik ovoga časopisa, recenziranje je obavio i neovisno uredničku odluku donio vanjski urednik izv. prof. dr. sc. Robert Župan (zamjenik glavnog urednika časopisa Geodetski list, ISSN: 0016-710X i član Uredničkog odbora časopisa AJET – Asian Journal of Engineering and Technology, ISSN: 2321-2462). Zahvaljujemo izv. prof. dr. sc. Robertu Županu na pomoći vezanoj uz potencijalni sukob interesa urednika.

Sažetak. Generalizacija geoinformacija može se podijeliti na generalizaciju modela i kartografsku generalizaciju. Generalizacija modela je nadzirano reduciranje podataka u modelu, a kartografska generalizacija je umanjivanje složenosti sadržaja karte prilagođeno mjerilu i/ili svrsi karte s pomoću različitih postupaka generalizacije. Predmet istraživanja ovog rada je generalizacija geoinformacija sažimanjem. Općenito, sažimanje je spajanje susjednih istovrsnih objekata, kad je razmak između njih manji od minimalnih veličina. Većina istraživača u generalizaciji geoinformacija usmjerena je na linijske objekte. Međutim, pojava web-karata s točkastim objektima, te površinski kartogrami potaknuli su razvoj koncepata i algoritama za generalizaciju točkastih i površinskih objekata. Rad razmatra neke dosadašnje teorijske spoznaje i primjere uporabe sažimanja točkastih, linijskih i površinskih objekata. Testirani su algoritmi za sažimanje u komercijalnim i slobodnim GIS softverima. U zaključku su istaknuti neriješeni izazovi koji se javljaju u dinamičnim kartografskim prikazima i u slučaju neuobičajenih geometrijskih objekata.

Ključne riječi: sažimanje, generalizacija geoinformacija, generalizacijski postupak, kartografska generalizacija, GIS, web-karte

1. Uvod

Razvojem digitalnih tehnologija tijekom zadnja dva desetljeća, izrada i upotreba karata jako su se promijenili. Dok je prije 20 godina glavno navigacijsko sredstvo bila papirnata karta, današnje karte na mobilnim elektroničkim uređajima pružaju korisnicima informacije o lokaciji, nude optimalne rute kretanja i mnoge druge informacije o traženoj lokaciji. Moglo bi se reći da je svjet bez interaktivnih karata na mobilnim telefonima i računalima danas gotovo nezamisliv.

Tehnološke promjene izvršile su snažan utjecaj na međusobno povezana znanstvena polja kartografiju i geografiju. Geoinformacijski sustavi (GIS) kao alat u znanstvenim istraživanjima i geoinformatika kao znanost posljedičan su odgovor na ovu fundamentalnu tehnološku promjenu u geografiji i srodnim disciplinama. Slična se promjena dogodila i u kartografiji, tako da je tehnološka revolucija uvjetovala prijelaz s analogne na digitalnu kartografiju. Proces izrade i prezentacije karata postao je brži, jeftiniji, liberalniji i raznolikiji.

Pojavom novih izlaznih medija javljaju se nove prilike i izazovi, osobito u kartografskoj generalizaciji, koja je ključan kartografski proces. Važnost apstrakcije podataka sve je važnija u informacijskom društvu – u kojem količina podataka premašuje naše mogućnosti njihova primanja (Bereuter, 2015).

1.1. Pojmovi i definicije

Generalizacija geoinformacija je najširi pojam koji se može podijeliti na generalizaciju modela / generalizaciju baze podataka (dobivanje reduciranih baza podataka iz izvorne) i kartografsku generalizaciju (proces dobivanja grafičkog produkta ili vizualizacije iz baze podataka ili druge karte krupnijeg mjerila) (Brassel i Weibel, 1988; Haunert i Wolff, 2010).

Prema Frančuli (2003), *kartografska generalizacija* je proces smanjenja složenosti sadržaja karte prilagođeno mjerilu i/ili svrsi karte.

Za provođenje kartografske generalizacije upotrebljavaju se različiti *postupci generalizacije* za smanjenje

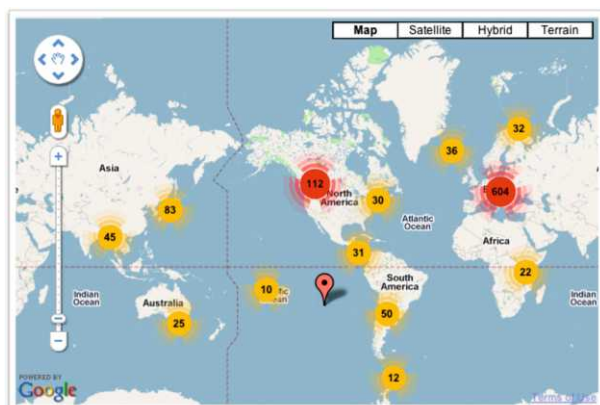


Fig. 1 Representation of point location markers on a small-scale web-map, before and after aggregation (URL 1)

Slika 1. Prikaz točkastih položajnih oznaka na web-karti u sitnom mjerilu prije i nakon sažimanja (URL 1)

evolve when attempting to represent the relevant objects in a final cartographic representation on a reduced surface. The number and names of generalization operators (procedures), and their significance, depend on the author. McMaster and Shea (1992) have differentiated 12 operators: “simplification”, “smoothing”, “aggregation”, “amalgamation”, “merging”, “collapse”, “refinement”, “exaggeration”, “enhancement”, “displacement”, “symbolization”, and “classification”. Robinson et al. (1995) list four: “classification”, “simplification”, “exaggeration”, and “symbolization”, while Frančula (2003) identifies six: “selection”, “simplification”, “aggregation”, “exaggeration”, “displacement”, and “collapse”. Generalization operators define particular a generalization process at the conceptual level (e.g. aggregation), implemented by *generalization algorithms*. For a single generalization operator, several generalization algorithms may exist (McMaster and Shea, 1992).

The topic of this paper is the generalization of geoinformation by *aggregation*. Aggregation is defined as the “joining of nearby congenial objects, when the distance between them is smaller than the minimum sizes” (Frančula, 2003, p. 27). Minimum sizes are sizes less than

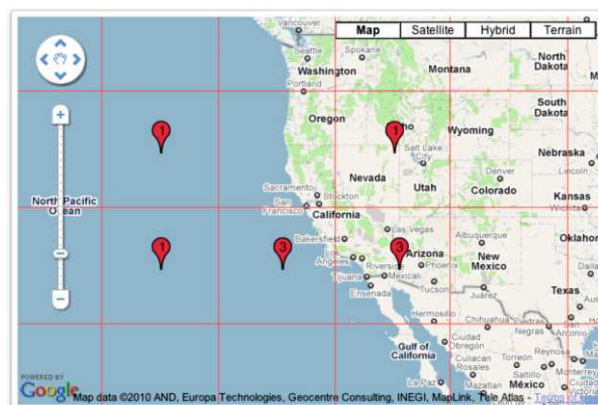
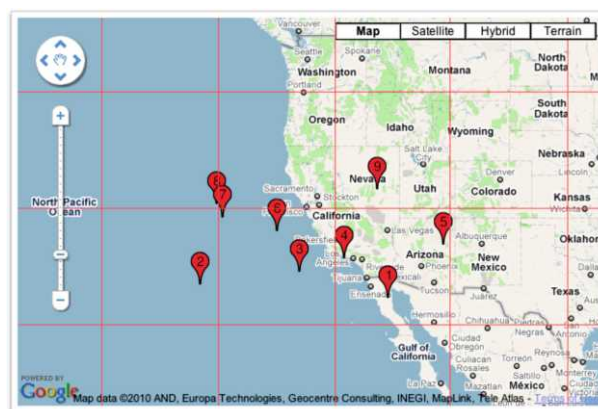


Fig. 2 Representation of point location markers on a web-map before and after square grid aggregation (URL 1)

Slika 2. Prikaz točkastih položajnih oznaka na web-karti prije i poslije sažimanja s pomoću kvadratne mreže (URL 1)

which a graphical element cannot be visually recognized. It should be noted that many authors divide aggregation into sub-groups. For example, DeLucia and Black (1987) divide aggregation into three operators by geometrical dimensionality: the “agglomeration” of several polygonal features into a single polygonal feature, i.e. at equal dimensionality; the “aggregation” of several point features into a single polygonal feature, i.e. upward conversion in dimensionality; and the “collapse” of a feature by changing its cartographic form, i.e. a downward conversion in dimensionality. McMaster and Shea (1992) divide aggregation into the “aggregation” of point features, “amalgamation” of polygonal features, and “merging” of line features. Stanislawski et al. (2014) cite “aggregation” as the replacement of features by a feature at a higher dimension, “merging” at an equal dimension; and “collapsing” at a lower dimension etc. In this paper, the term ‘aggregation’ includes any kind of grouping of objects (at equal, lower and higher geometrical dimensionalities).

In the following chapters, several earlier theoretical perceptions and examples of geoinformation aggregation use will be considered, software implementations tested, and the unresolved challenges noted.

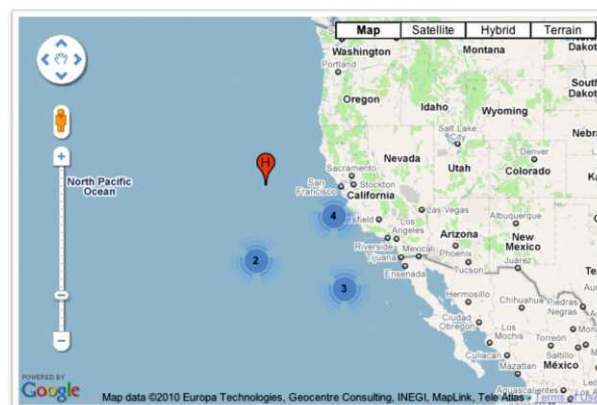
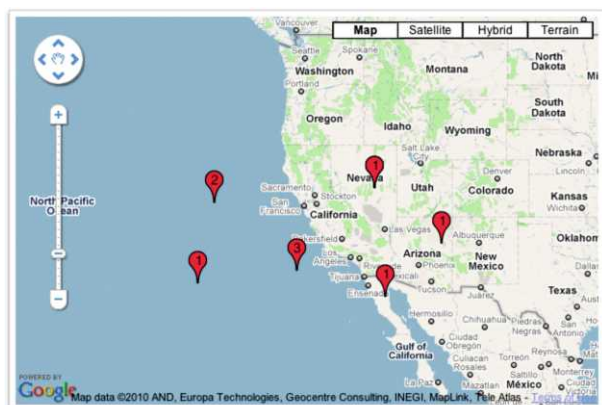
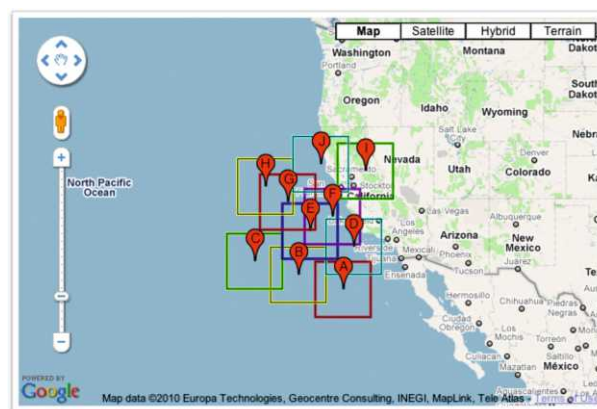


Fig. 3 Representation of point location markers on a web-map before and after buffer zone aggregation (URL 1)

Slika 3. Prikaz točkastih položajnih oznaka na web-karti prije i poslije sažimanja s pomoću udaljenosti od središta grupe (URL 1)

Fig. 4 Representation of point location markers on a web-map before and after aggregation by the *MarkerClusterer* algorithm in the *Google Maps* library (URL 1)

Slika 4. Prikaz točaka na web-karti prije i poslije sažimanja algoritmom u biblioteci *Google Mapsa MarkerClusterer* (URL 1)

prostornih sukoba koji nastaju pri pokušaju da se na manjoj raspoloživoj površini prikažu značajni objekti za konačni kartografski prikaz. Broj i nazivi postupaka generalizacije, kao i njihovo značenje ovise o autoru. McMaster i Shea (1992) razlikuju 12 postupaka generalizacije: pojednostavnjenje (engl. *simplification*), izgladivanje (engl. *smoothing*), sažimanje točkastih objekata (engl. *aggregation*), sažimanje površinskih objekata (engl. *amalgamation*), sažimanje linijskih objekata (engl. *merging*), potpuna ili djelomična pretvorba metode prikaza (engl. *collapse*), pročišćavanje (engl. *refinement*), naglašavanje (engl. *exaggeration*), poboljšavanje (engl. *enhancement*), pomicanje (engl. *displacement*), simbolizacija (engl. *symbolization*) i klasifikacija (engl. *classification*). Robinson i dr. (1995) navode ih četiri (klasifikacija, pojednostavnjenje, naglašavanje i simbolizacija), Frančula (2003) razlikuje šest (izbor, pojednostavnjivanje, sažimanje, naglašavanje, pomicanje, pretvorba metode prikaza) itd. Postupci generalizacije definiraju pojedini generalizacijski proces na konceptijskoj razini (npr. sažimanje), a provode se *generalizacijskim algoritmima*. Za jedan generalizacijski postupak može postojati više generalizacijskih algoritama (McMaster i Shea, 1992).

Predmet istraživanja ovog rada je generalizacija geoinformacija *sažimanjem*. Sažimanje se definira kao „spajanje susjednih istovrsnih objekata, kad je razmak između njih manji od minimalnih veličina“ (Frančula, 2003, str. 27). Minimalne veličine su veličine ispod kojih se neki grafički element ne može vizualno raspoznati. Treba naglasiti da mnogi autori dijele sažimanje na podskupove. Tako na primjer, DeLucia i Black (1987) dijele sažimanje na tri postupka prema geometrijskoj dimenzionalnosti: sažimanje više površinskih objekata u jedan površinski objekt, tj. na jednaku dimenzionalnost (engl. *agglomeration*); sažimanje više točkastih objekata u jedan površinski objekt, tj. na višu dimenzionalnost (engl. *aggregation*) i sažimanje objekata na nižu dimenzionalnost pretvorbom metode prikaza (engl. *collapse*). McMaster i Shea (1992) dijele sažimanje na sažimanje točkastih objekata (engl. *aggregation*); sažimanje površinskih objekata (engl. *amalgamation*) i sažimanje linijskih objekata (engl. *merging*). Stanislawski i dr. (2014) navode sažimanje na višu dimenzionalnost (engl. *aggregation*); sažimanje na jednaku dimenzionalnost (engl. *merge*) i sažimanje na nižu dimenzionalnost (engl. *collapse*), itd. U ovom radu pojam

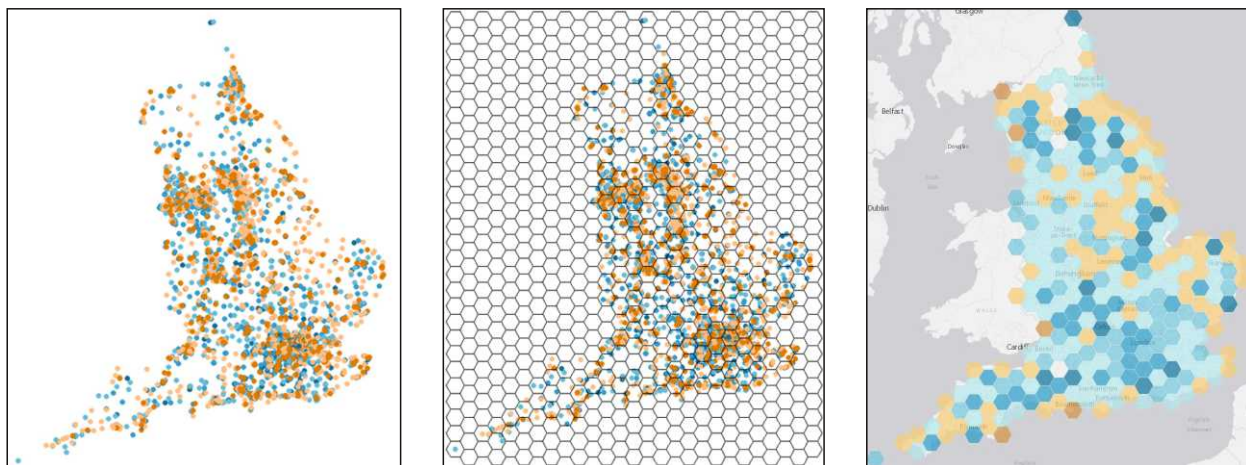


Fig. 5 Representation of points on a web-map before and after aggregation by the binning method (URL 2)

Slika 5. Prikaz točaka na web-karti prije i poslije sažimanja s pomoću metode pakiranja (URL 2)

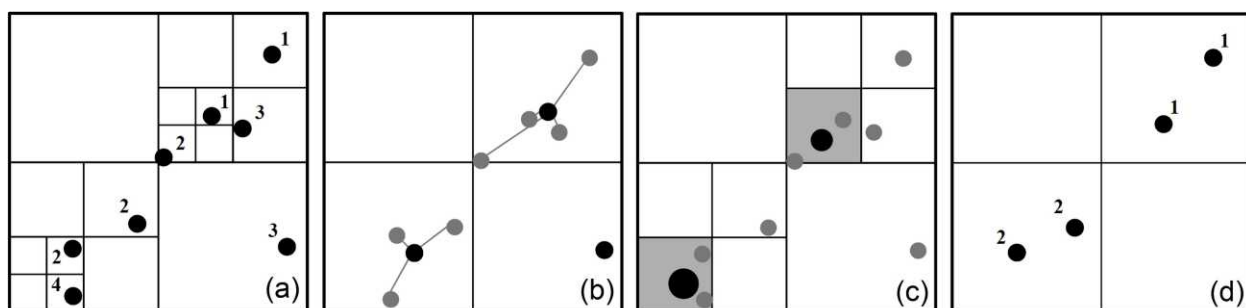


Fig. 6 Aggregation algorithms for point features: (a) source data and quadtree; (b) midpoint aggregation; (c) cluster-based aggregation; (d) collocation filtering (Bereuter and Weibel, 2013)

Slika 6. Algoritmi sažimanja točkastih objekata: (a) izvorni podaci i kvadratno stablo; (b) sažimanje u središnju točku; (c) na grupama zasnovano sažimanje; (d) kolokacijsko filtriranje (Bereuter i Weibel, 2013)

2 Theoretical Perceptions and Examples of Aggregation Usage

During the process of generalization using aggregation, the grouping of smaller objects (e.g. small forest areas) is performed first, and these are then replaced by a single object (an aggregate of forests) in a smaller scale (Haunert and Wolff, 2010). The specific characteristic of aggregation, in contrast to selection and simplification, is that it creates objects in new locations (Bereuter and Weibel, 2010). Aggregation, apart from generalization, can be used for the anonymization of confidential spatial information, such as individual trajectories (Andrienko and Andrienko, 2011) or the locations of patients or victims of crime (Leitner and Curtis, 2004).

Most researchers in geoinformation generalization focus on line features (Bereuter and Weibel, 2010). However, the proliferation of web-maps with point features and choropleth maps have led to the development of concepts and algorithms for the generalization of point and polygonal features. So, theoretical perceptions and

examples of aggregation use will be presented separately for point, line and polygonal features. Although aggregation is also applied to the generalization of 3-D features (Kada, 2011), this exceeds the scope of the paper.

2.1 Aggregation of point features

Over the past few years, point data have risen in importance due to new cartographic challenges, such as the advent of point-of-interest (POI) data in web and mobile cartography applications, and the predominance of point geometries in geospatially relevant applications (Bereuter and Weibel, 2010).

If a small-scale web-map contains many point location markers, they tend to overlap, so the map is difficult to read and interaction is harder to achieve (Fig. 1) (URL 1).

Aggregation on interactive web-maps can be implemented using set of algorithms, whereby the hierarchical performance of generalization procedures enables a pre-generalized representation. Other methods enable real-time (*on-the-fly*) representation and geoinformation



Fig. 7 Original trajectories (left) aggregated by parameters of 500 metres (middle) and 100 metres (right) (Andrienko and Andrienko, 2011)

Slika 7. Izvorne trajektorije (lijevo) sažete s parametrima 500 metara (sredina) i 100 metara (desno) (Andrienko i Andrienko, 2011)

sažimanja uključuje bilo koji oblik grupiranja objekata (na jednaku, nižu i višu geometrijsku dimenzionalnost).

U idućim će se poglavljima razmotriti neke dosadašnje teorijske spoznaje i primjeri uporabe sažimanja geoinformacija, iskušat će se softverske realizacije i upozoriti na neriješene izazove.

2. Teorijske spoznaje i primjeri upotrebe sažimanja

Prilikom generalizacije sažimanjem, prvo se provodi grupiranje manjih objekata (npr. malih šumskih površina), koji se potom zamjenjuju jednim objektom (skup šuma) u sitnijem mjerilu (Haunert i Wolff, 2010). Posebnost sažimanja u odnosu na izbor i pojednostavnjenje je što ona stvara objekte na novim lokacijama (Bereuter i Weibel, 2010). Sažimanje se, osim za generalizaciju, može rabiti i za anonimizaciju povjerljivih prostornih informacija, poput individualnih trajektorija (Andrienko i Andrienko, 2011) ili lokacija bolesnika i žrtava kriminala (Leitner i Curtis, 2004).

Većina istraživača u generalizaciji geoinformacija usmjerena je na linijske objekte (Bereuter i Weibel, 2010). Međutim, ekspanzija web-karata s točkastim objektima i površinskih kartograma potaknula je razvoj koncepata i algoritama za generalizaciju točkastih i površinskih objekata. Zbog toga će se teorijske spoznaje i primjeri upotrebe sažimanja izložiti odvojeno za točkaste, linijske i površinske objekte. Premda se sažimanje primjenjuje i u generalizaciji 3D-objekata (Kada, 2011), to premašuje opseg ovog rada.

2.1. Sažimanje točkastih objekata

Tijekom posljednjih nekoliko godina, točkasti podaci dobili su na važnosti zbog novih kartografskih izazova – pojave podataka na mrežnim i mobilnim kartografskim aplikacijama u obliku točaka od interesa (engl. *point-of-*

interest – POI), kao i prevlast točkaste geometrije u geoprostorno relevantnim aplikacijama (Bereuter i Weibel, 2010).

Kada na web-karti u sitnom mjerilu ima mnogo točkastih položajnih oznaka, one se preklapaju pa karta postaje nečitljiva i teže je ostvariti interakciju (slika 1) (URL 1).

Sažimanje na interaktivnim web-kartama može se provesti s pomoću skupa algoritama, gdje hijerarhijsko provođenje postupaka generalizacije omogućuje unaprijed generaliziran prikaz. Druge metode omogućuju prikazivanje i generalizaciju geoinformacija u realnom vremenu (engl. *on-the-fly*). To se ostvaruje hijerarhijskim strukturama podataka, kao što su *k-d stabla*, *kvadratna stabla* (engl. *quadrees*) ili *reaktivna stabla* (Bereuter i Weibel, 2010).

Najjednostavnija metoda sažimanja točaka je s pomoću kvadratne mreže. Polje prikaza karte u određenom mjerilu podijeli se na kvadratna polja, a sve točke koje se nalaze u jednom polju mreže, zamjenjuju se novim točkastim znakom u središtu kvadrata (slika 2). Nedostatak te metode je što prostorno bliske točke (npr. 7 i 8 na slici 2) mogu biti dodijeljene različitim grupama.

Sažimanje temeljeno na udaljenosti slično je prethodnoj metodi, samo što se umjesto kvadratne mreže upotrebljava kružno područje zadanog polumjera oko središta grupe. Ako je udaljenost točaka od središta grupe manja od zadanog polumjera, one će se sažeti i zamijeniti jednim točkastim znakom (slika 3).

Najbolje rezultate za sažimanje točaka u sklopu *Google Maps API*-ja daje biblioteka *MarkerClusterer*. Algoritam radi iteracije kroz skup točaka i pridružuje ih najbližoj grupi ako se nalaze unutar granica minimalnog okvira definiranog pikselima. Markeri se pritom zamjenjuju novim kružnim znakom s naznačenim brojem grupiranih objekata (slika 4) (URL 1).

U predprogramiranim generaliziranim prikazima točaka upotrebljava se i metoda sažimanja poznata pod engleskim nazivom *binning*, što bi se moglo prevesti kao




Fig. 8 Aggregation of hurricane trajectories by averaging distance raster (adapted from Scheitlin et al., 2013)

Slika 8. Sažimanje trajektorija uragana s pomoću usrednjavanja rastera udaljenosti (prilagođeno prema Scheitlin i dr., 2013)

generalization. This is achieved by hierarchical data structures, such as *k-d trees*, *quadrees* or *reactive trees* (Bereuter and Weibel, 2010).

The simplest method for point aggregation is the use of a square grid. A map canvas in the given scale is divided into square fields, and all points in a single field of the grid are replaced by a new point marker in the centre of the square (Fig. 2). The disadvantage of this method is that spatially close points (e.g. 7 and 8 on Fig. 2) can be assigned to different groups.

Aggregation based on distance is similar to the previous method, but instead of a square grid, the buffer zone defined around the centre of the group is used. If the distance between the points and the group centre is smaller than the defined buffer radius, the points will be aggregated and replaced by a single point marker (Fig. 3).

The *MarkerClusterer* library gives the best results for point aggregation in *Google Maps API*. The algorithm iterates through a set of points and joins them to the closest cluster, if they are inside the limits of the minimum frame defined by pixels. Markers are then replaced by a new circle symbol with an indicated number of aggregated features (Fig. 4) (URL 1).

In pre-programmed generalized representations of points, the aggregation method known as *binning* is also used. This approach is similar to the aggregation of points by a square grid, but here, a hexagonal grid is used and point markers are replaced by a homogenous field in a certain colour (Fig. 5) (URL 2).

Quadtree structures show good properties for the real-time generalization of a cartographic representation (Fig. 6). Geometrical measurements help inform the generalization algorithms and parameterize their output. Local measurements are derived from each quadnode, such as the number of points in the sub-tree,

maximum depth, size and balancing. Global measurements are based on the complete dataset, such as total number of points, density, or spatial distribution.

Midpoint aggregation performs generalization according to the geometrical mean centre point of quadnode sub-tree points.

Clustering-based aggregation produces highly-clustered, densely-populated quadnodes with a high number of occupied quadnode sub-trees, based on the positions and attributes of the points.

Collocation filtering generalizes quadnodes based on a collocation rule, such as the co-occurrence of features in a quadnode belonging to the same class, or capturing logical relationships between different point categories (Bereuter and Weibel, 2013).

2.2 Aggregation of line features

Aggregation of line features is most commonly applied in thematic cartography, e.g. for the representation of movement data, or trajectories in so-called *flow maps*.

Andrienko and Andrienko (2011) have proposed an algorithm for the aggregation of line trajectories that extracts specific points from the trajectory, groups them with regard to spatial distance, and uses the centres of these groups as generating points for *Voronoi tessellation* of the territory. The resulting Voronoi polygons are used as places for aggregating movement data and creating flow maps. The degree of generalization depends on the size of the polygons which, in turn, depend on the spatial extent of the point groups. The desired spatial extent (radius) is a parameter of the method. In Fig. 7, the original trajectories and aggregated lines are shown, depending on the set values of the



Fig. 9 Aggregation of double-lines into single lines by conversion into polygons and *Delaunay triangulation* (Wang and Doihara, 2004)

Slika 9. Sažimanje dvostrukih linija u jednostruke pretvaranjem u poligone i *Delauneyevom triangulacijom* (Wang i Doihara, 2004)

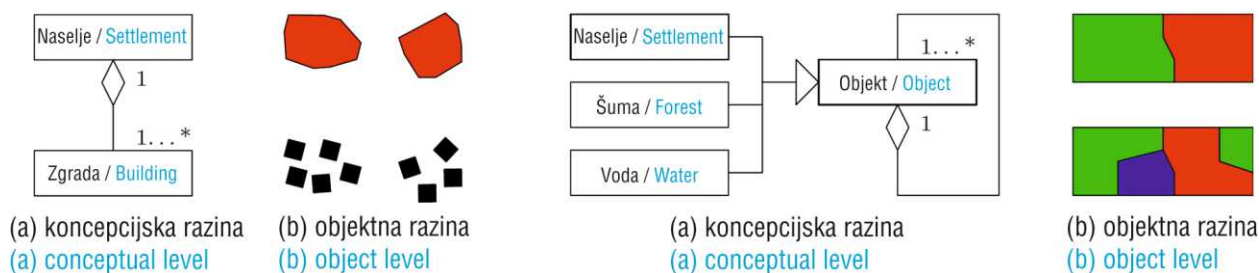


Fig. 10 Aggregation of spatially disjoint features, planar subdivision features and conceptual and object level (adapted from Haunert, 2008)

Slika 10. Sažimanje prostorno odvojenih i kontinuirano povezanih površinskih objekata na konceptijskoj i objektnoj razini (prilagođeno prema Haunert, 2008)

„pakiranje“. Pristup je sličan sažimanju točaka s pomoću kvadratne mreže, samo što se ovdje upotrebljava šesterokutna mreža i točkasti se znakovi zamjenjuju homogenim poljem određene boje (slika 5) (URL 2).

Strukture kvadratnih stabala pokazuju dobra svojstva za generalizaciju kartografskog prikaza u realnom vremenu (slika 6). Geometrijske mjere služe za pojašnjenje generalizacijskih algoritama i parametrizaciju njihova izlaza. Lokalne mjere izводе se iz svakog kvadrata, primjerice broj točaka u podkvadratu, najveća dubina, veličina i uravnoteženje podkvadrata. Globalne mjere temelje se na cijelom skupu podataka, kao što je ukupni broj točaka, gustoća ili prostorna razdioba.

Sažimanje u središnju točku (engl. *midpoint aggregation*) provodi generalizaciju s pomoću točke koja je u geometrijskom središtu između točaka u kvadratu podstabla.

Sažimanje temeljeno na grupiranju (engl. *clustering-based aggregation*) vraća jako grupirane i gusto ispunjene kvadrate s velikim brojem ispunjenih podkvadrata, ovisno o položajima i atributima točaka.

Kolokacijsko filtriranje (engl. *collocation filtering*) generalizira kvadrate temeljem kolokacijskog pravila, kao npr. višestruko pojavljivanje objekta iste klase u kvadratu ili određivanje logičkih veza između različitih kategorija točaka (Bereuter i Weibel, 2013).

2.2. Sažimanje linijskih objekata

Sažimanje linijskih objekata najčešće se primjenjuje u tematskoj kartografiji, npr. kada se prikazuju podaci o

kretanju pojava, odnosno trajektorije na tzv. *kartama toka* (engl. *flow map*).

Andrienko i Andrienko (2011) predložili su algoritam za sažimanje linijskih trajektorija koji izdvaja određene točke iz trajektorije, grupira ih prema prostornoj udaljenosti i upotrebljava središta tih grupa kao tvorne točke za *Voronojevu teselaciju* područja. Nastali Voronojevi poligoni rabe se kao područja za sažimanje podataka kretanja i stvaranje karte toka. Stupanj generalizacije ovisi o veličini poligona, koja pak ovisi o prostornom pružanju skupina točaka. Željeni prostorni obuhvat (radijus) je parametar metode. Na slici 7 prikazane su izvorne trajektorije i sažete linije ovisno o veličini zadanog parametra. Što je veći parametar, veći je stupanj sažimanja, odnosno generalizacije.

Pretpostavka opisanog algoritma je da ne postoje *prethodno određena važna mjesta* (početak i kraj linije ili križanje linija) u mreži, kao što je to slučaj u većini drugih algoritama za sažimanje linija. Umjesto toga, pronađen je način *određivanja prigodnih mjesta* za sažimanje podataka o kretanju i izradu karata toka.

Osim za analizu i vizualizaciju prometnih tokova, sažimanje višestrukih trajektorija može se provesti za praćenje i predviđanje trajektorija uragana. Prvi korak je povezivanje individualnih točaka na kojima je zabilježeno kretanje središta uragana u linijsku trajektoriju, stvaranje rastera udaljenosti i računanje aritmetičke sredine svih trajektorija iz rastera udaljenosti (slika 8) (Scheitlin i dr., 2013).

Najčešća primjena sažimanja linija u topografskoj kartografiji je pretvaranje dvostrukih kolničkih linija u




Fig. 11 Aggregation of polygons according to the rules of constrained *Delauney triangulation*, user-defined threshold distance = 5 (adapted from Ghosh and Amato, 2014)

Slika 11. Sažimanje poligona po pravilima uvjetovane *Delauneyeve triangulacije*, zadani parametar udaljenosti = 5 (prilagođeno prema Ghosh i Amato, 2014)

parameter. If the parameter is larger, the level of aggregation, i.e. generalization, is higher.

This algorithm assumes that there is no *predefined set of relevant places* (start and end of lines, or line intersections) in a network, as is the case for most other algorithms for aggregation of lines. Rather, a way was found to *define suitable places* for aggregating movement data and creating flow maps.

Apart from the analysis and visualization of traffic flows, the aggregation of multiple trajectories can be used to track and predict hurricane trajectories. The first step involves connecting individual points, in which the progression of the centre of the hurricane is recorded in a line trajectory, creating a distance raster and calculating the average of all trajectories from the distance raster (Fig. 8) (Scheitlin et al., 2013).

The most common application of aggregation of lines in topographic cartography is in the conversion of double-line roads into single lines. One option is to convert double-line segments first into polygons. Next, *Delauney triangulation* is performed, to extract the centreline of the road (Fig. 9) (Wang and Doihara, 2004).

2.3 Aggregation of polygonal features

Polygonal features in GIS are the most complex, and the most demanding in terms of generalization. In the aggregation of polygonal features, two situations are

usually encountered: when the polygons are spatially disjoint (e.g. buildings, islands), and when they form a planar subdivision (e.g. administrative units, land use) (Fig. 10) (Haunert, 2008).

The aggregation of disjoint polygonal features will be described using the example of buildings. The algorithm proposed by Ghosh and Amato (2014) first defines objects and their surroundings using the *convex hull* operation. Vertices from the edges of the polygons are connected by line segments following the rules of *constrained Delauney triangulation*. Thus, a *neighbourhood graph* is created, in which vertices are assigned weights, i.e. the shortest distances from neighbouring objects. If the distance between the vertices in the graph is shorter than the user-defined threshold distance, the objects are aggregated (Fig. 11).

Wang and Doihara (2004) implemented a similar algorithm. First, the shortest links between polygonal features were determined, and then sorted by length in ascending order. If the lengths were shorter than the defined parameter, the features were added to the group. When grouping was complete, the features were aggregated (Fig. 12).

If polygonal features are adjacent and cover the entire area of cartographic representation, three basic aggregation scenarios are possible. Aggregating polygons that share a common boundary is the simplest, and is equivalent to eliminating the common boundary chain.




Fig. 12 Grouping of polygonal objects for aggregation (Wang and Doihara, 2004)

Slika 12. Grupiranje površinskih objekata za sažimanje (Wang i Doihara, 2004)

jednostruke. Jedna od mogućnosti je prvo pretvoriti dvostruke linijske segmente u poligone. Potom se provodi *Delauneyeva triangulacija* kako bi se izdvojila srednja crta prometnice (slika 9) (Wang i Doihara, 2004).

2.3. Sažimanje površinskih objekata

Površinski su objekti najsloženiji u GIS-u, pa su i najzahtjevniji za generalizaciju. Obično se pri sažimanju površinskih objekata susreću dvije situacije – kada su poligoni prostorno razdvojeni (npr. zgrade, otoci) i kada predstavljaju područja kao dijelove u kontinuiranoj ravlini (npr. administrativne jedinice, način uporabe zemljišta) (slika 10) (Haunert, 2008).

Sažimanje razdvojenih površinskih objekata opisat će se na primjeru zgrada. Algoritam koji su predložili Ghosh i Amato (2014) prvo definira objekte i njihovo susjedstvo s pomoću operacije *konveksne ljuske* (engl. *convex hull*). Čvorovi iz granica poligona povezuju se sa susjedstvom s pomoću linijskih segmenata po pravilima *uvjetovane Delauneyeve triangulacije*. Tako nastaje takozvani *graf susjedstva* u kojemu se čvorovima pridružuju težine, tj. najkraće udaljenosti do susjednih objekata. Ako je udaljenost između čvorova u grafu kraća od korisnički zadane udaljenosti, objekti se spajaju (slika 11).

Sličan su algoritam realizirali Wang i Doihara (2004). Prvo se određuju najkraće veze između površinskih objekata, koje se sortiraju prema rastućim vrijednostima duljina. Ako su udaljenosti kraće od zadanog parametra, objekti se pridružuju grupi. Kad se provede grupiranje, objekti se sažimaju (slika 12).

Ako su površinski objekti spojeni i pokrivaju cijelo područje kartografskog prikaza, moguća su tri osnovna

scenarija sažimanja. Najjednostavnije je sažimanje isto-vrsnih poligona koji imaju zajedničku granicu, a svodi se na eliminaciju zajedničkog segmenta. Ta funkcija dostupna je u gotovo svim GIS softverima. Drugi slučaj javlja se kad se sažimaju dva poligona iste kategorije, a razdvaja ih preuzak poligon koji pripada drugoj kategoriji (slika 13a). Treći, i najsloženiji je slučaj kada su dva poligona različitih kategorija razdvojena preuskim poligonom koji pripada trećoj kategoriji. Tada treba izračunati novu granicu između poligona koji se sažimaju (slika 13b i 13c) (Bader i Weibel, 1997).

Potreba za sažimanjem raznovrsnih poligona koji su spojeni ili razdvojeni drugim poligonima česta je pri generalizaciji topografskih baza podataka. Jednostavniji algoritmi, koji uzimaju u obzir veličinu susjedstva ili duljinu zajedničke granice, ne pokazuju dobre rezultate jer može doći do eliminacije malih rascijepanih područja (slika 14) (Haunert i Wolff, 2010).

Umjesto postavljanja isključivo čvrstih uvjeta, bolje rezultate pruža uvođenje „mekih“ uvjeta. Neki od uvjeta mogu biti semantička udaljenost (npr. bolje je sažeti šume i travnjake, nego šume i naselja kao u gornjem primjeru) i kompaktnost poligona. Nadalje, poželjno je upotrebljavati optimizacijske tehnike kako bi rezultati bolje oponašali ručnu generalizaciju (slika 15) (Haunert i Wolff, 2010).

3. Softverske provedbe algoritama za sažimanje

Komercijalni softver ArcGIS vjerojatno nudi najveći broj algoritama za sažimanje svih geometrijskih tipova. U ovome je istraživanju testiran alat za sažimanje točaka *Aggregate Points*. Jedini ulazni parametar bila je udaljenost,




Fig. 13 (a) Polygons of the same category that are too close (the background polygon buffer shows overlap); (b) and (c) two polygons belonging to different categories are aggregated (part of the background polygon is eliminated) and a new boundary is inserted (Bader and Weibel, 1997)

Slika 13. (a) Poligoni iste kategorije koji su preblizu (koridor (*buffer*) na poligonu u pozadini pokazuje preklap); (b) i (c) dva poligona različitih kategorija se sažimaju (dio poligona u pozadini se uklanja) i umeće se nova granica (Bader i Weibel, 1997)

This function is available in all major GIS. The second scenario arises when polygons of the same category are aggregated, but the polygon of the other category separating them is too narrow (Fig. 13a). The third, most complex scenario occurs when the intervening space between two polygons belonging to different categories is too narrow, and itself belongs to the third category. In this case, a new boundary between the aggregated polygons must be found (Fig. 13b and 13c) (Bader and Weibel, 1997).

The requirement for the aggregation of miscellaneous polygons which are adjacent or separated by other polygons is common to the generalization of topographic databases. Simpler algorithms that take into account neighbourhood size or common boundary length do not yield satisfying results, because small, sliver polygons can be eliminated (Fig. 14) (Haunert and Wolff, 2010).

Instead of setting exclusively hard constraints, better results are yielded by the implementation of “soft” constraints. Some of these constraints may be semantic distance (for example, it is better to aggregate forests and grasslands, rather than forests and settlements, as in the previous example), or the compactness of polygons. In addition, it is valid to use optimisation techniques for results, to imitate better manual generalization (Fig. 15) (Haunert and Wolff, 2010).

3 Software Implementations of Algorithms for Aggregation

The commercial ArcGIS software probably provides the greatest number of algorithms for the aggregation of all geometrical types. In this research, the *Aggregate Points* tool for the aggregation of points was tested. The only input parameter was distance, and points were aggregated into polygons, if they were closer to each other

than the distance (Fig. 16). Algorithms for more complex objects, e.g. *Merge Divided Roads* require more input parameters, and they are sensitive to geometrical and attribute errors, as was detected in this research using *OpenStreetMap* data.

Most the GIS software has an option for merging adjacent polygons belonging to the same class. In our research, the *Dissolve* tool in QGIS 2.12 open-source software was tested. The input data were parts of a lake located in different countries, separated into two polygons by the border. Aggregation was performed on the basis of a mutual attribute (i.e. the name). The result was a single polygon (Fig. 17).

4 Unresolved Challenges

Today, interactive web maps with point features are most often used. Aggregation in such cases can be pre-programmed, enabling cartographic rules to be followed better, but reducing flexibility. On the other hand, aggregation in real-time (on-the-fly) sacrifices cartographic quality in favour of achieving flexibility of representation. Methods that combine the advantages of both approaches have not yet been developed (Bereuter and Weibel, 2012). Also, the potential is still lacking for algorithms to react to the user adjusting the cartographic representation as needed (e.g. selecting layers that increase spatial conflicts), apart from changing the scale. In order to resolve this, approaches should be developed that connect interaction between the user and computer in feedback with automated generalization (Bereuter, 2015; Bereuter and Weibel, 2010).

In the aggregation of double-line features into single lines, the algorithms have problems with complicated intersections, overpasses and underpasses, which remain unresolved (Fig. 18) (URL 3).



Fig. 14 Simple algorithm for the aggregation of adjacent polygonal features: (left) input; (right) result (adapted from Haunert and Wolff, 2010)

Slika 14. Jednostavni algoritam za sažimanje spojenih površinskih objekata: (a) ulaz; (b) rezultat (prilagođeno prema Haunert i Wolff, 2010)



Fig. 15 Aggregation of polygonal features using the optimisation approach: (left) result with minimal class change; (middle) considering class change and compactness; (right) at a scale of 1:250,000 (adapted from Haunert and Wolff, 2010)

Slika 15. Sažimanje površinskih objekata primjenom optimizacijske tehnike: (lijevo) rezultat s minimalnom promjenom klase; (sredina) uzimanje u obzir promjene klase i kompaktnosti; (desno) u mjerilu 1:250 000 (prilagođeno prema Haunert i Wolff, 2010)

a točke su sažete u poligone ako su bile međusobno bliže od te udaljenosti (slika 16). Algoritmi za složenije objekte, npr. *Merge Divided Roads* zahtijevaju više ulaznih parametara, a osjetljivi su na greške u geometriji i atributima, što je u ovome istraživanju utvrđeno na podacima iz *OpenStreetMapa*.

Većina softvera za GIS ima opciju za spajanje istovrsnih poligona koji imaju zajedničku granicu. U našem je istraživanju testiran alat *Dissolve* unutar programa otvorenog koda QGIS 2.12. Ulazni podaci bili su dijelovi istog jezera koji se nalaze u drugim državama pa su razdvojeni granicom u dva poligona. Spajanje je provedeno na temelju zajedničkog atributa (npr. naziv). Rezultat je bio jedinstveni poligon (slika 17).

4. Neriješeni izazovi

Danas se najčešće rabe interaktivne web-karte s točkastim objektima. Sažimanje se pritom može pred-

programirati, što omogućuje bolje poštivanje kartografskih pravila, no umanjuje se fleksibilnost. Sažimanje u realnom vremenu, tj. na zahtjev, pak žrtvuje kartografsku kvalitetu kako bi se postigla fleksibilnost prikaza. Metode koje kombiniraju prednosti obaju pristupa još nisu razvijene (Bereuter i Weibel, 2012). Također, nedostaje mogućnost algoritama da, osim na promjenu mjerila, odgovore na korisnikovo prilagođavanje kartografskog prikaza svojim potrebama (npr. izbor slojeva koji povećavaju prostorne sukobe). Kako bi se to riješilo, treba razvijati pristupe koji povezuju interakciju korisnika i računala u sprezi s automatskom generalizacijom (Bereuter, 2015; Bereuter i Weibel, 2010).

Kod sažimanja dvostrukih linijskih objekata u jednostruke, algoritmi imaju problema sa složenim raskrižjima, nadvožnjacima i podvožnjacima, koji ostaju neriješeni (slika 18) (URL 3).

Sažimanje površinskih objekata koji su premali, preuski ili preblizu drugima, važan je problem za koji još




Fig. 16 Result of *Aggregate Points* operation in the ArcGIS: (left) input points; (center) aggregation of points into polygons; (right) output polygons

Slika 16. Rezultat operacije *Aggregate Points* u ArcGIS-u: (lijevo) ulazne točke; (sredina) sažimanje točaka u poligone; (desno) izlazni poligoni

The aggregation of polygonal features that are too small, too narrow, or too close to each other, is a major problem for which unique, simple solutions do not yet exist. Metric constraints of minimal sizes and width measures are available in the literature, but they are usually defined for simple regular polygons (buildings), rather than for irregular shapes. Metric constraints can collide, for instance, when a polygon has an area which is greater than the minimal, but very elongated, so that its width is less than the minimal (Bader and Weibel, 1997). So, “soft” constraints, such as topological, semantic, and *Gestalt*, are desirable (Haunert, 2008).

The aggregation of lines and other geometrical features can be applied in the anonymization of individual trajectories and protection of location privacy (Andrienko and Andrienko, 2011). However, the aggregation of data changes their statistical and spatial properties, so the use of such data affects the results of analysis negatively. Therefore, a compromise should be sought between satisfying anonymization and data quality (Bian and Butler, 1999).

5 Conclusion

New technology has led to an increase in various cartographic representations. However, this does not mean that all representations are of high enough quality. In many cases, cartographic generalization, which is a key process in cartography, is not carried out consistently.

Judging by its unaligned terminology, we can conclude that aggregation is the most variable, or least clear generalization operator. These features are unavoidable in generalizing all types of geometrical features in cartographic representations and spatial databases.

This paper reviews basic theoretical perceptions and the implementation of algorithms for the aggregation of

specific geometrical features (points, lines and polygons). Real-time aggregation of point features, in combination with hierarchical data structures, and taking into account interaction between the user and computer, will improve cartographic presentation significantly. The greatest numbers of methods and algorithms have been developed for the generalization of lines, but they are aimed mainly at simplification, and aggregation is not sufficiently emphasised. The greatest problems seem to arise with software implementation of algorithms for aggregation of lines, because of its sensitivity to geometrical and attribute errors in spatial data. Polygonal objects are the most complicated, so algorithms should be developed that could include “soft” constraints, by applying optimisation techniques to imitate human generalization better.


Hardly any algorithms and generalization operators require a map scale or other key generalization factors (minimum sizes, map purpose or data properties) as input parameters. If the input parameter is distance or area, it may be associated with the map scale or minimum sizes, but this makes it more difficult for users to apply, and if values are set incorrectly, unexpected or disappointing results may be obtained. So, additional resources should be employed to design algorithms and generalization operators that will enable easier, more intuitive use, thereby producing better results.

Aggregation is not used exclusively for the generalization of cartographic representations, but also for the protection of private data. In such cases, attention should be paid to keeping the statistical properties of data for spatial analysis purposes.

Overall, aggregation is one of the most demanding and ubiquitous generalization operators, and there are many challenges that need to be resolved in its implementation.

Fig. 17 Result of the *Dissolve* operation in QGIS using the polygon example: (left) input polygons; (right) merged (aggregated) polygons

Slika 17. Rezultat operacije *Dissolve* u QGIS-u na primjeru poligona: (lijevo) ulazni poligoni; (desno) spojeni (sažeti) poligoni



ne postoje jedinstvena i jednostavna rješenja. Metrički uvjeti minimalnih veličina i širina dostupni su u literaturi, ali samo za pravilne poligone (zgrade), dok za nepravilne oblike nisu definirani. Tako može doći do sukoba metričkih uvjeta, npr. kada neki poligon ima veću površinu od minimalne, ali je jako izdužen pa ima manju širinu od minimalne (Bader i Weibel, 1997). Zato je poželjno uvesti i „meke“ uvjete, kao što su topološki, semantički i *Gestalt* uvjeti (Haurert, 2008).

Sažimanje linijskih i drugih geometrijskih objekata može poslužiti za anonimizaciju individualnih trajektorija i zaštitu lokacijske privatnosti (Andrienko i Andrienko, 2011). Međutim, sažimanje podataka mijenja njihova statistička i prostorna svojstva pa uporaba takvih podataka loše utječe na rezultate analize. Stoga treba pronaći kompromis između zadovoljavajuće anonimizacije i kvalitete podataka (Bian i Butler, 1999).

5. Zaključak

Nove tehnologije dovele su do ekspanzije raznih kartografskih prikaza. Međutim, to ne znači da su svi ti prikazi dovoljno kvalitetni. Na mnogim od njih ne provodi se dosljedno kartografska generalizacija, koja je ključan kartografski proces.

Sudeći po neusklađenom nazivlju, sažimanje je najraznovrsniji ili najmanje jasan generalizacijski postupak. U svakom slučaju, nezaobilazan je pri generalizaciji svih vrsta geometrijskih objekata u kartografskim prikazima i bazama prostornih podataka.

Ovaj rad je prikazao temeljne teorijske spoznaje i provedbe algoritama za sažimanje specifičnih geometrijskih objekata (točaka, linija i područja). Sažimanje točkastih objekata u realnom vremenu s kombinacijom hijerarhijskih struktura podataka i uzimanjem u obzir interakcije korisnika i računala znatno će poboljšati kartografsku prezentaciju. Za generalizaciju linija osmišljen je najveći broj metoda i algoritama, no tu je uglavnom riječ o pojednostavljenju, dok sažimanju nije posvećena dovoljna pozornost. Problemi sa softverskim provedbama algoritama za sažimanje linija pokazali su se najveći zbog osjetljivosti na pogreške u geometriji i




Fig. 18 Problems in the aggregation of double lines (adapted from URL 3)

Slika 18. Problemi kod sažimanja dvostrukih linija (prilagođeno prema URL 3)

atributima prostornih podataka. Površinski objekti su najslabiji pa treba razvijati algoritme koji će primjenom optimizacijskih tehnika moći uzeti u obzir „meke“ uvjete te tako bolje oponašati ljudski način generalizacije.

Gotovo svi algoritmi, pa time i postupci sažimanja kao ulazne parametre ne zahtijevaju mjerilo karte ili neki drugi ključni čimbenik generalizacije (minimalne veličine, namjena karte ili značajke podataka). Kada je ulazni parametar udaljenost ili površina ona se može posredno povezati s mjerilom karte ili minimalnim veličinama, međutim to korisnicima otežava njihovu primjenu i u slučaju pogrešno zadanih vrijednosti parametara mogu se dobiti neočekivani ili razočaravajući rezultati. U tom smislu, potrebno je uložiti dodatne napore u oblikovanje algoritama i postupaka za generalizaciju koji će omogućiti njihovu lakšu i intuitivniju upotrebu, a samim time i kvalitetnije rezultate.

Sažimanje se ne upotrebljava samo za generalizaciju kartografskih prikaza, nego i za zaštitu osobnih podataka. Pri tome treba voditi računa o očuvanju statističkih svojstava podataka za potrebe prostornih analiza.

Sve u svemu, sažimanje je jedan od najzahtjevnijih i najprisutnijih generalizacijskih postupaka, u čijoj realizaciji postoje još mnogi izazovi koje treba riješiti.

References / Literatura

- Andrienko N., Andrienko G. (2011) Spatial Generalization and Aggregation of Massive Movement Data, *IEEE Transactions on Visualization and Computer Graphics*, 17 (2), 205–219
- Bader M., Weibel R. (1997) Detecting and resolving size and proximity conflicts in the generalization of polygonal maps, in: *Proceedings of the 18th International Cartographic Conference*, Stockholm, 23–27 June 1997, 1–9
- Bereuter P. (2015) Quadtree-based Real-time Point Generalisation for Web and Mobile Mapping, Dissertation (PhD), Mathematisch-naturwissenschaftlichen Fakultät, Universität Zürich
- Bereuter P., Weibel R. (2010) Generalisation of point data for mobile devices: A problem-oriented approach, in: *Proceedings of the 13th Workshop on Progress in Generalisation and Multiple Representation ICA Commission on Generalisation and Multiple Representation*, 1–8
- Bereuter P., Weibel R., (2012) Algorithms for On-the-Fly Generalization of Point Data Using Quadrees, in: *Proceedings of AutoCarto 2012*, Columbus, OH, USA, 16–18
- Bereuter P., Weibel R. (2013) Real-time generalization of point data in mobile and web mapping using quadrees, *Cartography and Geographic Information Science*, 40 (4), 271–281
- Bian L., Butler R. (1999) Comparing Effects of Aggregation Methods on Statistical and Spatial Properties of Simulated Spatial Data, *Photogrammetric Engineering & Remote Sensing*, 65 (1), 73–84
- Brassel K. E., Weibel R. (1988) A review and conceptual framework of automated map generalization, *International Journal of Geographical Information Systems*, 2 (3), 229–244
- DeLucia A., Black R., (1987) Comprehensive approach to automatic feature generalization, in: *Proceedings of the 13th International Cartographic Conference*, Morelia, Mexico, 12–21 October 1987, 169–192
- Frančula N. (2003) Kartografska generalizacija, Faculty of geodesy, University of Zagreb
- Ghosh M., Amato N. M. (2014) Hierarchical distance-based aggregation, Technical Report TR14-006, Texas A&M University
- Haunert J. H. (2008) Aggregation in Map Generalization by Combinatorial Optimization, Dissertation (PhD), Fakultät für Bauingenieurwesen und Geodäsie, der Gottfried Wilhelm Leibniz Hannover
- Haunert J. H., Wolff A. (2010) Area aggregation in map generalisation by mixed-integer programming, *International Journal of Geographical Information Science*, 24 (12), 1871–1897
- Kada M. (2011) Aggregation of 3D Buildings Using a Hybrid Data Approach, *Cartography and Geographic Information Science*, 38 (2), 153–160
- Leitner M., Curtis A. (2004) Cartographic Guidelines for Geographically Masking the Locations of Confidential Point Data, *Cartographic Perspectives*, 49, 22–39
- McMaster R. B., Shea K. S. (1992) *Generalization in Digital Cartography*, Association of American Geographers, Washington D.C.
- Robinson A. H., Morrison J. L., Muehrcke P. C., Kimerling A. J., Guptill S. C. (1995) *Elements of Cartography*, 6th Edition, Wiley, New York
- Scheitlin K. N., Mesev V., Elsner J. B. (2013) Polyline averaging using distance surfaces: A spatial hurricane climatology, *Computers & Geosciences*, 52, 126–131
- Stanislawski L. V., Battenfield B. P., Bereuter P., Savino S., Brewer C. A. (2014) Generalisation Operators, in: Burghardt D.; Duchêne C.; Mackaness W. (Eds.), *Abstracting Geographic Information in a Data Rich World, Methodologies and Applications of Map Generalisation*, Springer, New York, 159–162
- Wang P. T., Doihara T. (2004) Automatic Generalization of Roads and Buildings, in: *Proceedings of the 20th ISPRS*, Vol. XXXV, part B4, Comm. IV, Istanbul, Turkey, 249–254
- URL 1: Google, <https://developers.google.com/maps/articles/toomanymarkers> (December 21, 2015)
- URL 2: ESRI, <http://blogs.esri.com/esri/arcgis/2012/06/08/using-a-binning-technique-for-point-based-multiscale-web-maps/> (December 21, 2015)
- URL 3: ESRI, <https://desktop.arcgis.com/en/desktop/latest/tools/cartography-toolbox/collapse-dual-lines-to-centerline.htm> (December 23, 2015)